

Um Método Baseado em Dados para Detecção e Diagnóstico de Falhas em Unidades de Tratamento de Ar

David P. Azevedo * , Bruno C. Diniz ** , Leonardo R. Rodrigues *

* Instituto Tecnológico de Aeronáutica - ITA
São José dos Campos-SP, Brasil
(e-mail: david.azevedo@qa.ita.br, leonardolrr2@fab.mil.br)

** Universidade Federal da Bahia - UFBA, Salvador-BA, Brasil
(e-mail: bruno.diniz@ufba.br)

Abstract: Air Handling Units (AHUs) are essential refrigeration equipment to provide thermal comfort in buildings and commercial establishments. However, the maintenance strategies adopted for AHUs have low efficiency. In addition to the higher energy consumption, an AHU with a high degradation level has a higher probability of presenting a failure event. Many establishments have both the automation and the sensors needed to benefit from the data generated by the air handling systems. A fault detection and diagnosis (FDD) method can benefit from these data in order to identify inefficiencies in AHUs, allowing the implementation of an efficient maintenance strategy. This paper presents a data-driven method that uses Artificial Neural Networks with the Random Forest algorithm to identify the operation condition of AHUs, to alert the operator in case of a failure event. The results observed in numerical experiments show an accuracy of 99.3% and a computed F_1 -score of 0.983. The model was tested with new data and the results kept satisfactory.

Resumo: Unidades de Tratamento de Ar (UTAs) são equipamentos de refrigeração essenciais para proporcionar conforto térmico em edifícios e grandes estabelecimentos comerciais. No entanto, os mecanismos de manutenção de tais sistemas ainda costumam ser pouco eficientes. Além do maior gasto energético, uma UTA em funcionamento incorreto está mais propensa a apresentar um evento de falha. Muitos estabelecimentos já possuem a automação e a instrumentação necessárias para se beneficiar dos dados gerados pelos sistemas de tratamento de ar. Um método para detecção e diagnóstico de falhas pode se beneficiar amplamente destes dados para identificar ineficiências nos sistemas de ar-condicionado, permitindo a implementação de uma estratégia de manutenção mais eficiente. Este artigo propõe um método baseado no uso de Redes Neurais Artificiais com o algoritmo *Random Forest* para realizar a classificação das condições de operação do equipamento, visando alertar os operadores em caso de falhas. Os resultados obtiveram uma acurácia de 99,3% e F_1 -score de 0,983. O modelo foi posteriormente testado de forma mais exaustiva com o uso de novos dados e os resultados mantiveram-se satisfatórios.

Keywords: Fault Detection; Fault Diagnosis; Data-Driven Methods; Artificial Neural Networks; Random Forests; Air Handling Units.

Palavras-chaves: Detecção de Falhas; Diagnóstico de Falhas; Métodos Baseados em Dados; Redes Neurais Artificiais; Árvores Aleatórias; Unidades de Tratamento de Ar.

1. INTRODUÇÃO

Sistemas de Aquecimento, Ventilação, Ar Condicionado e Refrigeração (AVACR) são essenciais para garantir o conforto térmico e a qualidade do ar ambiente. Entretanto, apesar da importância socioeconômica de tais equipamentos, seus mecanismos de manutenção tendem a ser pouco eficientes, principalmente em estabelecimentos comerciais e residenciais.

Geralmente, a perda de desempenho das máquinas de ar condicionado intensifica seu consumo energético e aumenta os custos com manutenção. Essas consequências,

no entanto, não são percebidas pelos ocupantes das instalações. Essa perda de desempenho pode ser identificada com o uso de dispositivos de monitoramento contínuo e de procedimentos automatizados para detecção e diagnóstico de falhas. Em outros setores, o uso de tais técnicas já é bastante comum, como na indústria química, automotiva e aeronáutica devido ao alto valor agregado dos produtos de tais segmentos (Navarro-Esbrí *et al.*, 2006).

No estudo publicado por Downey e Proctor (2002), dentre os mais de 13.000 equipamentos de refrigeração avaliados, 65% dos equipamentos que operavam em instalações residenciais e 71% dos equipamentos que operavam em

estabelecimentos comerciais necessitavam de reparos. Moris *et al.* (2004) avaliaram máquinas de ar condicionado com e sem válvula de expansão termostática durante o período de 3 anos, e constataram que 72% das máquinas apresentavam carga incorreta de refrigerante e 44% das máquinas não proviam o fluxo de ar necessário.

Máquinas de condicionamento de ar, como as Unidades de Tratamento de Ar (UTAs), podem se beneficiar amplamente de uma ferramenta de monitoramento da condição do sistema. O objetivo de tal tecnologia é identificar a degradação dos equipamentos e do sistema de forma automática, preferencialmente em estágios iniciais, evitando uma avaria de maior proporção e garantindo que o equipamento cumpra os requisitos necessários de higiene e qualidade do ar local.

Nas últimas duas décadas, um trabalho extensivo de pesquisa vem sendo realizado sobre a aplicação de técnicas de *Fault Detection and Diagnosis* (FDD) em equipamentos AVACR. A detecção da falha é realizada através de uma comparação do desempenho atual do sistema com as medidas feitas em uma condição de operação adequada (Kim *et al.*, 2008b). A diferença entre a resposta atual do sistema e uma resposta “nominal” caracteriza o grau e o tipo de falha presente no sistema. O processo pode ser conduzido de diferentes formas: através de soluções analíticas, a partir do conhecimento prévio de um especialista ou baseado em dados históricos. Os estudos iniciais sobre o tema compreendiam o uso de limites fixos e regras empíricas para efetuar a detecção e o diagnóstico das falhas. Alguns trabalhos publicados utilizavam modelos analíticos para prever o comportamento do sistema (Wagner e Shoureshi, 1992; Kumamaru *et al.*, 1991), enquanto outros trabalhos simplesmente verificavam se os dados obtidos pela instrumentação encontravam-se dentro de margens estabelecidas com base em cálculos estatísticos ou pelo *know-how* de um profissional experiente (Stallard, 1989; Yoshimura e Noboru, 1989).

Em contrapartida, uma abordagem baseada no comportamento passado do equipamento pode aumentar o campo de exploração que se teria somente com modelos físicos do sistema ou a partir de regras pré-definidas. Choi *et al.* (2005) desenvolveram um método orientado por dados para detecção de falhas em *chillers* com base no teste da razão de verossimilhança generalizado. O algoritmo proposto por eles monitorava o desvio das variáveis de controle em relação ao seu valor nominal histórico. As falhas estudadas foram diagnosticadas a partir de 3 procedimentos: (a) análise dinâmica de componentes principais de múltiplas vias; (b) método dos mínimos quadrados; e (c) máquinas de vetores de suporte. Também foi empregado o método dos mínimos quadrados para estimar o grau de severidade das falhas avaliadas.

Kim *et al.* (2008b) investigaram a aplicação de técnicas de FDD em um ar condicionado residencial com válvula de expansão termostática. Diversas falhas foram simuladas em um sistema instalado em ambiente controlado. Um modelo de referência sem falhas usava como entradas a umidade do ambiente interno e as temperaturas dos ambientes interno e externo. As saídas eram calculadas a partir de uma regressão polinomial de 3ª ordem, a qual demonstrou melhores resultados que os cálculos utilizando

uma Rede Neural Artificial (RNA). A detecção da falhas foi feita por meio de uma classificação estatística dos resíduos baseada em 2 tabelas de regras: uma para quando a válvula de expansão atuava e outra para quando a válvula estava saturada.

Observadas as contribuições feitas em estudos anteriores, o objetivo do presente trabalho é apresentar um método orientado por dados para o monitoramento da condição de uma UTA a partir de dados históricos obtidos de uma máquina real em funcionamento. O método proposto deve levar em consideração as condições ambientais interna e externa, pois essas condições podem afetar consideravelmente o funcionamento da máquina e as variáveis envolvidas no processo. Outro ponto a ser considerado é que, diferente de outros sistemas críticos que possuem tolerância zero para falhas, uma UTA comumente permite que falhas ocorram por um certo período de tempo sem afetar diretamente o conforto dos ocupantes (Li, 2009).

As demais seções deste artigo estão organizadas conforme descrito a seguir. A seção 2 descreve o conjunto de dados utilizados nos experimentos. A seção 3 apresenta o método proposto. Os resultados observados nos experimentos numéricos são apresentados e discutidos na seção 4. As conclusões do trabalho e oportunidades para trabalhos futuros são apresentadas na seção 5.

2. BASE DE DADOS

O dados utilizados no presente artigo foram provenientes do projeto de pesquisa RP-1312 da ASHRAE (Li e Wen, 2010; Li *et al.*, 2010). No projeto, duas UTAs similares (denominadas A e B) tiveram suas condições de operação monitoradas durante diferentes estações do ano.

Os testes foram executados com a UTA-B operando normalmente, enquanto diferentes condições de falha foram introduzidas na UTA-A. Cada uma das situações de falha foi armazenada em um conjunto de dados diário com frequência de amostragem de uma amostra minuto, totalizando 1.440 amostras por dia. Os experimentos originais aconteceram em diferentes estações do ano. No entanto, no presente artigo só foram considerados apenas os dados coletados durante o verão de 2007 por serem mais similares às condições do clima brasileiro. As falhas avaliadas são descritas abaixo:

- **F1:** *Damper* de exaustão emperrado em posição totalmente aberta;
- **F2:** *Damper* de exaustão emperrado em posição totalmente fechada;
- **F3:** Ventilador de retorno em velocidade fixa;
- **F4:** Falha total no ventilador de retorno;
- **F5:** Válvula da serpentina de resfriamento instável;
- **F6:** *Damper* de insuflamento emperrado em posição totalmente fechada;
- **F7:** Válvula da serpentina de resfriamento totalmente fechada;
- **F8:** Válvula da serpentina de resfriamento totalmente aberta;
- **F9:** Válvula da serpentina de resfriamento 15% aberta;
- **F10:** Válvula da serpentina de resfriamento 65% aberta;

- **F11:** *Damper* de insuflamento com vazamento de 45%;
- **F12:** *Damper* de insuflamento com vazamento de 55%;
- **F13:** Vazamento no duto de ar após ventilador de insuflamento;
- **F14:** Vazamento no duto de ar antes do ventilador de insuflamento.

Os componentes principais do sistema e a instrumentação utilizada são apresentados na Figura 1. Dentre os principais componentes¹, pode-se citar os *dampers* de ar externo (1), de exaustão (6) e de retorno (7); a válvula de controle da serpentina de resfriamento (2); a serpentina de resfriamento (3); os ventiladores de insuflamento (4) e de retorno (5); e os dutos de ar. Já a instrumentação consiste em medições de temperatura, umidade, potência elétrica, pressão e vazão de ar. Mais informações sobre a instalação podem ser encontradas em Price e Smith (2003) e em Li e Wen (2010).

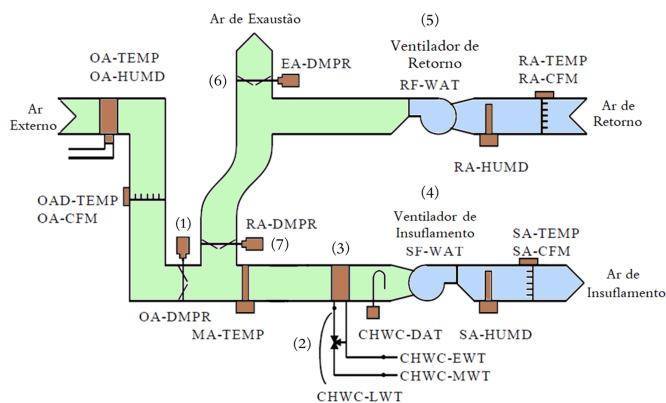


Figura 1. Diagrama esquemático das UTAs. Adaptado de Price e Smith (2003).

3. MÉTODO PROPOSTO

O método proposto tem como base os trabalhos de Kim *et al.* (2008b) e Vachtsevanos *et al.* (2006). O primeiro passo consiste no pré-processamento dos dados para diminuição dos ruídos de medição e eliminação de mudanças bruscas nas variáveis de controle. Em seguida, é criado um modelo de referência para caracterizar o estado nominal da máquina operando sem a ocorrência de falhas. Posteriormente, são calculados os resíduos entre as saídas do modelo de referência e as medições atuais do sistema. Esses resíduos são classificados em condições com e sem falha na etapa de detecção e diagnóstico. O método proposto é ilustrado na Figura 2.

3.1 Pré-processamento

A etapa de pré-processamento é essencial para filtragem e preparação dos dados brutos para serem utilizados no método proposto. Neste trabalho, foram selecionados somente os momentos em que a UTA se encontrava em regime permanente para a construção do modelo sem falhas. Segundo Kim *et al.* (2008b), quando um sistema não está em regime permanente, seu comportamento termodinâmico é

¹ Neste projeto foram desconsideradas as medições realizadas na serpentina de aquecimento e esta foi omitida da Figura 1 por não ser utilizada durante o verão.

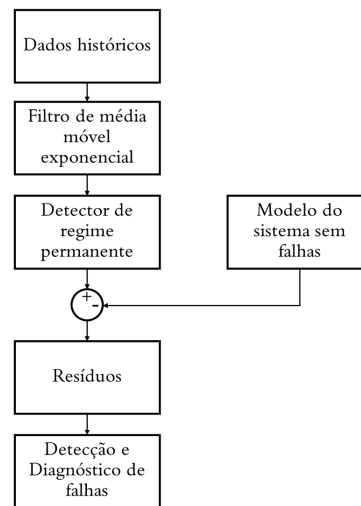


Figura 2. Modelo proposto para detecção e diagnóstico de falhas nas UTAs.

altamente instável, e tal instabilidade pode comprometer a acurácia do modelo de predição de falhas. O regime permanente é reconhecido quando não há mudanças abruptas nas variáveis de controle. A análise ocorre através de uma janela móvel de tempo. A cada nova amostra é avaliado se a soma das inclinações dos parâmetros observados estão acima de um certo limite, conforme proposto por Li (2009). A inclinação de uma variável, denominada $S(t)$, é calculada a partir dos valores máximo X_{max} , mínimo X_{min} e médio X_{mean} das amostras contidas na janela móvel, como apresentado na Equação (1).

$$S(t) = \frac{X_{max} - X_{min}}{X_{mean}} \quad (1)$$

O cálculo da inclinação total é feito com base na inclinação de todas as variáveis que alimentam o modelo FDD. Os dados referentes ao período entre 9h e 12h do dia 31/08/2007 foram escolhidos para estabelecer o limite aceitável de regime. Esse limite foi definido como 3 vezes o desvio-padrão da soma das inclinações dos parâmetros de controle, o que no presente trabalho corresponde ao valor de 0,15. Kim *et al.* (2008a) recomendam incluir todas as *features* no detector de regime permanente para garantir mais robustez à análise, uma vez que diferentes variáveis podem ter papéis chave em diferentes condições de regime transitório. Ademais, os autores realizaram diversos experimentos para determinar um tamanho adequado para a janela móvel, encontrando um valor ótimo de 10 amostras, sendo este valor mantido no método proposto.

Foi empregado, também, um filtro de média móvel exponencial, conforme apresentado na Equação (2), para a diminuição dos ruídos dos parâmetros tanto de entrada como de saída do sistema.

$$\bar{X}(t) = \lambda X(t) + (1 - \lambda)\bar{X}(t-1) \quad (2)$$

onde λ é o fator de esquecimento responsável por atribuir pesos maiores às amostras recentes, $X(t)$ é a amostra mais recente e $\bar{X}(t-1)$ é a média móvel das amostras do instante passado, calculado a partir da Equação (3).

$$\lambda = \frac{2}{span + 1} \quad (3)$$

onde $span$ é o tamanho da janela. Com uma janela definida de 10 amostras tem-se que $\lambda = 0,18$. A Figura 3 ilustra os resultados observados durante a etapa de pré-processamento dos dados.

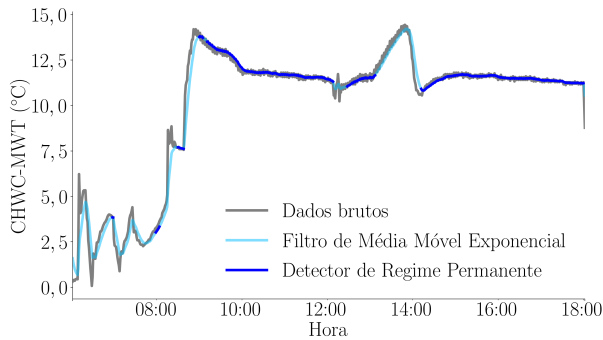


Figura 3. Exemplo do detector de regime permanente no comportamento da água de mistura da serpentina de resfriamento (CHWC-MWT).

3.2 Modelo de Referência sem Falhas

As redes neurais artificiais foram escolhidas para a construção do modelo de referência sem falhas. Essa técnica foi escolhida por ser versátil e escalável, tornando-a ideal para lidar com tarefas de aprendizado de máquina complexas e com grande quantidade de dados (Géron, 2017). A estrutura de rede com implementação mais trivial é a MLP (*Multi-Layer Perceptron*) que consiste em uma camada de entrada, seguida por um conjunto de camadas ocultas e, por fim, uma camada de saída. Como o processamento dos dados tem um sentido único (da camada de entrada para de saída) e todos os neurônios das camadas estão interligados, a rede é caracterizada como *feedforward* e totalmente conectada. Ao se adicionar mais camadas ocultas, o algoritmo é capaz de identificar e representar padrões mais complexos entre as variáveis, porém o custo computacional do modelo aumenta.

Além da definição da arquitetura da rede, é preciso estabelecer qual algoritmo de aprendizagem será empregado. Em outras palavras, é necessário escolher uma função objetivo e um otimizador. As redes neurais solucionam um problema de otimização, em que um algoritmo (otimizador) é utilizado para minimizar uma função (função objetivo). O “conhecimento” adquirido pelo modelo é armazenado através de matrizes, em que cada elemento, chamado de peso sináptico, está relacionado a um *link* entre dois neurônios. O processo de aprendizagem é realizado a partir da busca pelo conjunto de pesos que minimizam a função objetivo. O pesos são modificados a cada nova iteração, das camadas mais externas para as mais internas, aplicando a regra da cadeia para se obter a contribuição de cada parâmetro no valor total do erro (Chollet, 2017). Esse processo é também conhecido como algoritmo de retropropagação do erro. A dedução detalhada do algoritmo de retropropagação pode ser encontrada em Haykin (2009).

O modelo da RNA usado no presente trabalho foi desenvolvido utilizando a biblioteca de *deep learning* Keras (Chollet *et al.*, 2015) escrita em Python. O otimizador escolhido foi o Adam, um algoritmo de gradiente descendente estocástico, computacionalmente eficiente e conveniente para questões envolvendo grande quantidade de parâmetros (Kingma e Ba, 2014). A função objetivo selecionada foi o erro quadrático médio (MSE), adequado para regressões. O custo ou perda é calculado pela média do quadrado das diferenças entre o valor real da saída y e o seu valor previsto \hat{y} , como indicado na Equação (4).

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

onde N é o número total de observações.

Na modelagem de uma rede neural artificial é importante normalizar as variáveis de entrada para facilitar a aprendizagem da rede e evitar distorções nos pesos sinápticos. O método adotado no presente trabalho foi a normalização *Min-Max*, em que muda-se o intervalo de valores das variáveis de entrada para $[0,1]$. É importante destacar que no presente trabalho foram computados apenas os valores mínimo e máximo dos valores contidos no conjunto de treinamento para evitar a introdução de um viés na normalização dos dados. A normalização ocorre conforme apresentado na Equação (5).

$$x' = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (5)$$

onde x_i é o valor original da variável, $\max(x)$ é o máximo valor que a variável assume no conjunto de treinamento, $\min(x)$ é o mínimo valor que a variável assume no conjunto de treinamento, e x' é o valor normalizado da variável.

Mais de cem fatores foram monitoradas no conjunto de dados original e seria computacionalmente custoso propor um método de classificação de falhas utilizando todas as informações disponíveis. Dessa forma, foi escolhido um subconjunto de variáveis para o compor o modelo de referência. Essas variáveis são as que afetam de maneira mais significativa o conforto dos ocupantes e a energia consumida pelo sistema. As entradas escolhidas para o modelo (variáveis independentes) não podem ser controladas pela UTA e estão ligadas às condições ambientais interna e externa, que são apresentadas na Tabela 1. As saídas são parâmetros que podem ser controlados pelo equipamento e servirão de *features* para o algoritmo de classificação, como mostrado na Tabela 2.

Tabela 1. Parâmetros de entrada do modelo de referência sem falhas.

Variável	Descrição
OA-TEMP	Temperatura do ar externo
OA-HUMD	Umidade do ar externo
RA-TEMP	Temperatura do ar de retorno
RA-HUMD	Umidade do ar de retorno
CHWC-EWT	Temperatura de entrada da água gelada na serpentina de resfriamento

Tabela 2. Parâmetros de saída do modelo de referência sem falhas.

Variável	Descrição
SF-WAT	Potência do ventilador de insuflamento
RF-WAT	Potência do ventilador de retorno
MA-TEMP	Temperatura do ar de mistura
SA-TEMP	Temperatura do ar de insuflamento
SA-HUMD	Umidade do ar de insuflamento
SA-CFM	Fluxo do ar de insuflamento
RA-CFM	Fluxo do ar de retorno
CHWC-MWT	Temperatura da água de mistura
CC-WAT	Taxa de calor transferida pela serpentina de resfriamento

Para a construção dos modelos, o conjunto de dados foi dividido em dois terços para treinamento e um terço para teste. Os dados em regime permanente ao longo do período analisado representavam 10.648 amostras, resultando em 7.027 dados para treinamento e 3.621 para teste. Manteve-se o ordenamento dos dados durante a divisão pelo fato de serem séries temporais. Entretanto, dentro de cada subconjunto os dados foram embaralhados. Foi criada uma rede neural MLP do tipo MISO (*Multiple Input Single Output*) para cada uma das *features*, como exemplificado na Figura 4.

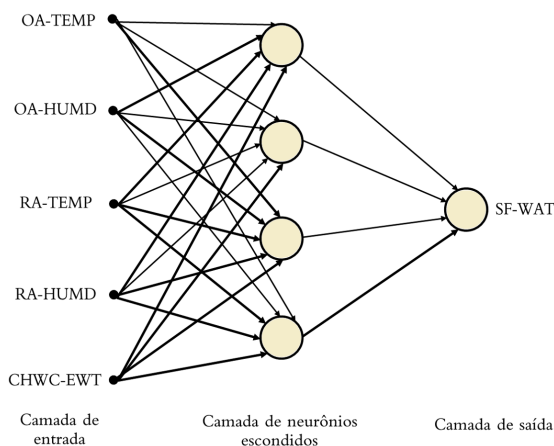


Figura 4. Estrutura da rede MLP proposta com cinco entradas, uma camada oculta e uma saída.

Buscou-se otimizar os parâmetros da rede neural com o objetivo de encontrar a configuração com menor coeficiente de determinação R^2 , calculado conforme Equação (6).

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (6)$$

onde \bar{y} é a média das amostras de saída.

O universo de valores considerado para os parâmetros de otimização está descrito na Tabela 3. Foi definido que a rede poderia utilizar até duas funções de ativação diferentes: uma para a camada de entrada e outra para as demais camadas.

Após a definição do universo de valores pra os parâmetros e a unidade de desempenho a ser otimizada, a busca pelo melhor modelo ocorreu de maneira aleatória (*Random Search*). Para evitar o *overfitting* do modelo durante a

Tabela 3. Universo de parâmetros de otimização do modelo RNA.

Parâmetro	Valores
Número de neurônios	8, 16, 32, 64, 128, 256
Número de camadas escondidas	1, 2, 3
Função de ativação inicial	<i>Sigmoid</i> , ReLu, <i>tanh</i>
Função de ativação das demais camadas	<i>Sigmoid</i> , ReLu, <i>tanh</i>
Taxa de aprendizagem	10^{-1} , 10^{-3} , 10^{-5}
Épocas	5.000, 10.000, 15.000

otimização, subdividiu-se o conjunto de treinamento em dois terços para o treinamento e um terço para validação. O treinamento da rede finaliza com antecedência caso o erro médio quadrático não diminuísse em pelo menos 2.000 épocas, reduzindo o tempo computacional do processo. Após a localização dos melhores parâmetros, o conjunto de teste foi usado para calcular o R^2 do modelo.

3.3 Detecção de Diagnóstico de Falhas

O modelo de detecção e diagnóstico de falhas foi construído com o algoritmo *Random Forest*, um método amplamente utilizado em problemas de classificação. Técnicas de árvores de decisão são uma das formas mais simples e ainda mais bem-sucedidas de aprendizado de máquina (Russell e Norvig, 2010). O *Random Forest* é uma versão mais avançada do procedimento tradicional de árvores de decisão devido ao emprego do aprendizado por agrupamento (*Emsemble Learning*). Essa técnica consiste em criar um grupo de classificadores, em que cada um é treinado com um subconjunto de dados diferente e escolhido aleatoriamente. Para realizar a predição, computa-se o resultado de cada classificador e, então, verifica-se qual a categoria mais prevista entre todos. Essa diversificação descorrelaciona os erros de identificação, o que melhora a acurácia do método e aumenta a robustez do algoritmo (Géron, 2017).

Foi utilizada a função *RandomForestClassifier* da biblioteca *scikit-learn* (Pedregosa *et al.*, 2011) escrita em *Python* para codificação do algoritmo. Além do critério de impureza (índice Gini ou entropia), foram alterados outros parâmetros do algoritmo como o número de classificadores e o número máximo de folhas em cada árvore. O processo de seleção desses parâmetros teve como objetivo maximizar o F_1 -score, uma medida que representa a média harmônica entre a precisão e o *recall* do modelo, caracterizada pela Equação (7).

$$F_1 = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (7)$$

A precisão e o *recall* são métricas calculadas a partir da matriz de confusão do classificador, na qual se compara as categorias reais com as preditas.

4. RESULTADOS

Após a realização da busca aleatória, foram encontrados os parâmetros que resultaram no menor R^2 para o modelo *fault-free* desenvolvido com as redes neurais. O melhor conjunto de parâmetros é apresentado na Tabela 4.

Tabela 4. Melhores parâmetros para a RNA encontrados após *Random Search*.

Parâmetro	Valor
Número de neurônios	256
Número de camadas escondidas	1
Função de ativação inicial	ReLU
Função de ativação das demais camadas	Sigmoid
Taxa de aprendizagem	10^{-5}
Épocas	15.000

Os melhores resultados encontrados possuem um alto número de neurônios quando comparado com trabalhos anteriores (Kim *et al.*, 2008b), baixa taxa de aprendizagem e numerosas épocas, tendendo a um maior tempo de treinamento. O desempenho final de cada *feature* com os parâmetros selecionados é satisfatório e está descrito na Figura 5.




Figura 5. Resultados do R^2 para cada uma das *features* do modelo de RNA.

A partir da diferença entre as saídas do modelo de referência e os dados em funcionamento da máquina, são calculados os resíduos para cada uma das 14 diferentes condições de falha apresentadas na seção 2. A condição de ausência de falhas é caracterizada como **F0**. Os resíduos foram classificados pelo módulo de detecção e diagnóstico de falhas. Os resultados de precisão, *recall* e F_1 -score para cada categoria de falha são apresentados na Tabela 5.

Tabela 5. Resultados do modelo de classificação com o algoritmo *Random Forest*.

Falha	Precisão	Recall	F_1 -score	Amostras
F0	0,998	1,000	0,999	3514
F1	1,000	0,989	0,994	181
F2	1,000	0,987	0,994	156
F3	0,991	1,000	0,996	113
F4	1,000	1,000	1,000	155
F5	1,000	0,958	0,979	48
F6	1,000	1,000	1,000	150
F7	1,000	1,000	1,000	103
F8	0,994	0,994	0,994	156
F9	1,000	0,984	0,992	61
F10	0,995	0,995	0,995	185
F11	0,988	1,000	0,994	166
F12	0,993	0,987	0,990	154
F13	1,000	1,000	1,000	133
F14	1,000	0,994	0,997	171

4.1 Avaliação do Método Proposto

O método proposto foi avaliado a partir de testes com o uso de novos dados que não foram apresentados ao modelo durante a etapa de treinamento.

O primeiro teste realizado teve como objetivo verificar a assertividade do modelo em classificar um comportamento ausente de falhas. Para isso, utilizou-se os dados da UTA-B no dia 10/09/2007 durante o período de funcionamento com ocupantes no ambiente. No intervalo descrito, a máquina operava corretamente e esses dados serviram de entradas para o modelo. O resultado da classificação é mostrado na Tabela 6.

Tabela 6. Classificação da operação em regime permanente sem falhas da UTA-B durante o dia 10/09/2007.

Falha	Frequência
F0	413
F11	2

Observou-se que o algoritmo foi capaz de classificar corretamente 99,5% dos dados (413 dentre 415 amostras) em condição normal de operação **F0**. Nos dois casos em que a classificação foi errada, a falha indicada foi a falha **F11**.

No segundo teste, foi averiguado se o modelo seria capaz de detectar uma falha conhecida, porém em um grau diferente de deterioração. A falha escolhida para este teste foi a falha **F7**, que caracteriza uma situação em que a válvula da serpentina encontra-se totalmente fechada. O modelo foi treinado omitindo-se os dados da falha **F9** (válvula da serpentina 15% aberta), a qual é similar à condição da falha **F7**, porém em grau diferente. Posteriormente, os dados do dia 01/09/2007 referentes à falha **F9** foram apresentados ao modelo e os resultados estão ilustrados na Tabela 7.

Tabela 7. Classificação da operação em regime permanente da UTA-B durante o dia 01/09/2007 sob condição de falha **F9**, sem que o modelo tenha sido apresentado a esses dados durante treinamento.

Falha	Frequência
F7	182
F3	2
F14	1

Como esperado, o algoritmo classificou corretamente 98,4% dos dados (182 dentre 185 amostras), sendo capaz de reconhecer similaridades entre o comportamento da máquina na mesma condição de falha, porém em diferentes graus de intensidade. Por fim, ressalta-se que modelo apresentou resultados satisfatórios para ambos os testes, comprovando seu potencial de robustez.

5. CONCLUSÃO

Sistemas de AVACR ainda carecem de estratégias mais ágeis para detecção e diagnóstico de falhas e, em sua maioria, já produzem dados necessários para isso. O presente trabalho foi capaz de apresentar um método baseado em

dados para identificação de irregularidades em uma UTA, que apresentou um desempenho satisfatório nos experimentos numéricos realizados.

O método proposto é aplicável a sistemas de automação predial, e se torna mais viável em uma UTA que já possui sua instrumentação instalada, como acontece em diversos estabelecimentos comerciais modernos. Essa aplicação funciona como um *gateway* em que os dados dos sensores presentes no equipamento são compartilhados com um sistema responsável por interpretar essas informações e indicar uma mal funcionalidade ou consumo excessivo de energia.

Apesar dos resultados satisfatórios, é importante ressaltar que os dados foram coletados em um ambiente controlado, assim como eram conhecidas a origem e grau das falhas aplicadas. Por vezes, não é possível ter esse grau de controle em uma operação comum, por isso é importante a aplicabilidade do modelo FDD em diversas condições de instalação. Outros métodos matemáticos, como o uso de redes neurais recorrentes ou a redução de dimensionalidade do *dataset*, podem ser utilizados para prover maior grau de generalização ao modelo e servem de sugestões para trabalhos futuros.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro (processo 423023/2018-7) e à Dra. Jin Wen, professora da universidade de Drexel, por ter gentilmente disponibilizado a base de dados utilizada neste trabalho.

REFERÊNCIAS

- Choi, K., Namburu, M., Azam, M., Luo, J., e Pattipati, K. (2005). Fault diagnosis in HVAC chillers using data-driven techniques. *IEEE Instrumentation Measurement Magazine*, 8(3), 24–32.
- Chollet, F. (2017). *Deep Learning with Python*. Manning, Shelter Island, NY.
- Chollet, F. et al. (2015). Keras. URL <https://keras.io>.
- Downey, T. e Proctor, J. (2002). What can 13,000 air conditioners tell us? *The Proceedings of the 2002 ACEEE Summer Study on Energy Efficiency in Buildings*, 1, 53–67.
- Géron, A. (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow : concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, Sebastopol, CA.
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Pearson Education, Hamilton, Ontario, Canada, 3ª edição.
- Kim, M., Yoon, S.H., Domanski, P.A., e Vance Payne, W. (2008a). Design of a steady-state detector for fault detection and diagnosis of a residential air conditioner. *International Journal of Refrigeration*, 31(5), 790 – 799.
- Kim, M., Yoon, S.H., Payne, W.V., e Domanski, P.A. (2008b). Cooling mode fault detection and diagnosis method for a residential heat pump. *National Institute of Standards and Technology*.
- Kingma, D. e Ba, J. (2014). Adam: A method for stochastic optimization. *International Conference on Learning Representations*.
- Kumamaru, T., Utsunomiya, T., Yamada, Y., Iwasaki, Y., Shoda, I., e Obayashi, M. (1991). Fault diagnosis system for district heating and cooling facilities. *Proceedings of the International Conference on Industrial Electronics, Control, and Instrumentation*, 131–136.
- Li, S. (2009). *A Model-Based Fault Detection and Diagnostic Methodology for Secondary HVAC Systems*. Ph.D. thesis, Drexel University.
- Li, S. e Wen, J. (2010). Development and validation of a dynamic air handling unit model - Part I (RP 1312). *ASHRAE Transactions*, 116, 45–56.
- Li, S., Wen, J., Zhou, X., e Klaassen, C.J. (2010). Development and validation of a dynamic air handling unit model - Part II (RP 1312). *ASHRAE Transactions*, 116, 57–73.
- Mowris, R.J., Blankenship, A., Jones, E., e Associates, R.M.. (2004). Field measurements of air conditioners with and without TXVs. *ACEEE 2004 Summer study on Energy Efficiency in Buildings*.
- Navarro-Esbrí, J., Torrella, E., e Cabello, R. (2006). A vapour compression chiller fault detection technique based on adaptative algorithms. application to on-line refrigerant leakage detection. *International Journal of Refrigeration*, 29, 716–723.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., e Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Price, B.A. e Smith, T.F. (2003). Development and validation of optimal strategies for building HVAC systems. *Technical Report: ME-TEF-03-001, Department of Mechanical Engineering, The University of Iowa*.
- Russell, S.J. e Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. Pearson Education, Upper Saddle River, New Jersey, 3ª edição.
- Stallard, L. (1989). *Model Based Expert System for Failure Detection and Identification of Household Refrigerators*. Master's thesis, Purdue University.
- Vachtsevanos, G., Lewis, F., Roemer, M., Hess, A., e Wu, B. (2006). *Intelligent fault diagnosis and prognosis for engineering systems*. Wiley, New Jersey.
- Wagner, J. e Shoureshi, R. (1992). Failure detection diagnostics for thermofluid systems. *Journal of Dynamic Systems, Measurement, and Control*, 114(4), 699–706.
- Yoshimura, M. e Noboru, I. (1989). Effective diagnosis methods for air-conditioning equipment in telecommunications buildings. *Proceedings of INTELEC 89: The Eleventh International Telecommunications Energy Conference*, 1–7.